



MODÉLISATION NON-LINÉAIRE

Sujets: prédicteur non-linéaire

• On a vu plusieurs algorithmes qui produisent des modèles linéaires (régression ou classification)

• Malheureusement, pas tous les problèmes peuvent être résolus avec un modèle linéaire

• Par contre, on peut obtenir des modèles non-linéaires à l'aide de fonctions de base non-linéaires







Sujets: fonctions de base polynomiales

• Exemple : fonctions

$$\phi_j(x) = x^j$$

• On retrouve alors la



APPROCHE PROBABILISTE DISCRIMINANTE

Sujets: fonctions de bases



HUGO LAROCHELLE

RAPPEL2 fonctions debases gaussiennes ϕ_j

 $-\frac{(x-\mu_j)^2}{2s^2}$ $\exp \langle$

Méthodes à Noyaux

Sujets: noyau, méthodes à noyaux

- On va maintenant voir une façon très simple d'introduire des fonctions de bases non-linéaires dans un modèle linéaire
 - les fonctions de bases vont être définies implicitement (pas besoin) de représenter explicitement en mémoire $\phi(\mathbf{x})$!)
 - on aura seulement à calculer une comparaison $k(\mathbf{x}, \mathbf{x}')$ entre les entrées x et \mathbf{x}'
- La fonction $k(\mathbf{x}, \mathbf{x}')$ est appelée un **noyau**
 - les algorithmes utilisant un noyau sont appelées méthodes à noyaux







Régression

Sujets: régression

• Revenons au problème de la régression (régularisée) :

$$J(\mathbf{w}) = \frac{1}{2} \sum_{n=1}^{N} \left\{ \mathbf{w}^{\mathrm{T}} \boldsymbol{\phi}(\mathbf{x}_{n}) - t_{n} \right\}^{2} + \frac{\lambda}{2} \mathbf{w}^{\mathrm{T}} \mathbf{w}$$

• Si on fixe le gradient par rapport à \mathbf{w} à 0, on observe que

$$\mathbf{w} = -\frac{1}{\lambda} \sum_{n=1}^{N} \left\{ \mathbf{w}^{\mathrm{T}} \boldsymbol{\phi}(\mathbf{x}_{n}) - t_{n} \right\} \boldsymbol{\phi}(\mathbf{x}_{n}) = \sum_{n=1}^{N} a_{n} \boldsymbol{\phi}(\mathbf{x}_{n}) =$$

HUGO LAROCHELLE

$= \mathbf{\Phi}^{\mathrm{T}} \mathbf{a}$

Régression

Sujets: régression

• Donc, la solution w est simplement une somme pondérée des entrées x_n dans l'ensemble d'entraînement

$$\mathbf{w} = \sum_{n=1}^{N} a_n \boldsymbol{\phi}(\mathbf{x}_n) = \boldsymbol{\Phi}^{\mathrm{T}} \mathbf{a}$$

où chaque a_n est la contribution de $\phi(\mathbf{x}_n)$ à la solution

• Idée : plutôt qu'optimiser par rapport à w, optimisons par rapport à a

 $(a_1,\ldots,a_N)^{\mathrm{T}}$

Sujets: représentation duale

• Si on remplace w par $\mathbf{\Phi}^{\mathrm{T}}\mathbf{a}$, on peut démontrer qu'on obtient

$$J(\mathbf{a}) = \frac{1}{2} \mathbf{a}^{\mathrm{T}} \boldsymbol{\Phi} \boldsymbol{\Phi}^{\mathrm{T}} \boldsymbol{\Phi} \boldsymbol{\Phi}^{\mathrm{T}} \mathbf{a} - \mathbf{a}^{\mathrm{T}} \boldsymbol{\Phi} \boldsymbol{\Phi}^{\mathrm{T}} \mathbf{t} + \frac{1}{2} \mathbf{t}^{\mathrm{T}} \mathbf{t} + \frac{1}{2} \mathbf{t}^{\mathrm{T}}$$

• C'est la **représentation duale** de $J(\mathbf{w})$



$-\frac{\lambda}{2}\mathbf{a}^{\mathrm{T}}\mathbf{\Phi}\mathbf{\Phi}^{\mathrm{T}}\mathbf{a}$

Sujets: représentation duale, matrice de Gram

• Si on remplace ${f w}$ par ${f \Phi}^{
m T}{f a}$, on peut démontrer qu'on obtient

$$J(\mathbf{a}) = \frac{1}{2}\mathbf{a}^{\mathrm{T}}\mathbf{K}\mathbf{K}\mathbf{a} - \mathbf{a}^{\mathrm{T}}\mathbf{K}\mathbf{t} + \frac{1}{2}\mathbf{t}^{\mathrm{T}}\mathbf{t} + \frac{\lambda}{2}\mathbf{a}^{\mathrm{T}}\mathbf{K}\mathbf{a}$$

- On va aussi noter $\phi(\mathbf{x}_n)^{\mathrm{T}}\phi(\mathbf{x}_m) = k(\mathbf{x}_n, \mathbf{x}_m)$
- La **matrice de Gram** K contient tous les

$$K_{nm} = k(\mathbf{x}_n, \mathbf{x}_m)$$

de l'ensemble d'entraînement



Sujets: représentation duale

• Si on remplace w par $\mathbf{\Phi}^{\mathrm{T}}\mathbf{a}$, on peut démontrer qu'on obtient

$$J(\mathbf{a}) = \frac{1}{2} \mathbf{a}^{\mathrm{T}} \mathbf{K} \mathbf{K} \mathbf{a} - \mathbf{a}^{\mathrm{T}} \mathbf{K} \mathbf{t} + \frac{1}{2} \mathbf{t}^{\mathrm{T}} \mathbf{t} + \frac{\lambda}{2} \mathbf{a}^{\mathrm{T}} \mathbf{K} \mathbf{a}$$

• En fixant à 0 les gradients par rapport à a, on obtient

$$\mathbf{a} = \left(\mathbf{K} + \lambda \mathbf{I}_N\right)^{-1} \mathbf{t}$$



Sujets: représentation duale

• Pour faire une prédiction :

$$y(\mathbf{x}) = \mathbf{w}^{\mathrm{T}} \boldsymbol{\phi}(\mathbf{x}) = \mathbf{a}^{\mathrm{T}} \boldsymbol{\Phi} \boldsymbol{\phi}(\mathbf{x}) = \mathbf{k}(\mathbf{x})^{\mathrm{T}} (\mathbf{K} + \lambda \mathbf{I})$$

où
$$\mathbf{k}(\mathbf{x}) = (k(\mathbf{x}_1, \mathbf{x}), \dots, k(\mathbf{x}_N, \mathbf{x}))^{\mathrm{T}}$$



$\left[N \right]^{-1} \mathbf{t}$

RÉGRESSION À NOYAU

Sujets: régression à noyau

- Algorithme de régression à noyau
 - entraînement : $\mathbf{a} = (\mathbf{K} + \lambda \mathbf{I}_N)^{-1} \mathbf{t}$
 - prédiction : $y(\mathbf{x}) = \mathbf{k}(\mathbf{x})^{\mathrm{T}}\mathbf{a}$
- Pour exécuter cet algorithme, on a seulement besoin de calculer les produits scalaires du noyau

$$\boldsymbol{\phi}(\mathbf{x}_n)^{\mathrm{T}}\boldsymbol{\phi}(\mathbf{x}_m) = k(\mathbf{x}_n, \mathbf{x}_m)$$

• Par contre, on doit toujours avoir accès aux entrées de l'ensemble d'entraînement







RÉGRESSION À NOYAU

Sujets: régression à noyau

- Algorithme de régression à noyau
 - entraînement : $\mathbf{a} = (\mathbf{K} + \lambda \mathbf{I}_N)^{-1} \mathbf{t}$
 - prédiction : $y(\mathbf{x}) = \mathbf{k}(\mathbf{x})^{\mathrm{T}}\mathbf{a}$
- Pour exécuter cet algorithme, on a seulement besoin de calculer les produits scalaires du noyau

$$\boldsymbol{\phi}(\mathbf{x}_n)^{\mathrm{T}}\boldsymbol{\phi}(\mathbf{x}_m) = k(\mathbf{x}_n, \mathbf{x}_m)$$



ASTUCE DU NOYAU

Sujets: astuce du noyau

- L'astuce du noyau vise à exploiter cet observation
 - peut-on définir des noyaux tels que calculer $k(\mathbf{x}_n, \mathbf{x}_m)$ est plus efficace que de calculer $\phi(\mathbf{x}_n)$ et $\phi(\mathbf{x}_m)$ et ensuite faire $\phi(\mathbf{x}_n)^{\mathrm{T}} \phi(\mathbf{x}_m)$?



ASTUCE DU NOYAU

Sujets: astuce du noyau

- La réponse est oui !
- 3 multiplications et I addition • Exemple (D=2): $k(\mathbf{x}, \mathbf{z}) = (\mathbf{x}^{\mathrm{T}} \mathbf{z})^{2} = (x_{1} z_{1} + x_{2} z_{2})^{2}$ $= x_1^2 z_1^2 + 2x_1 z_1 x_2 z_2 + x_2^2 z_2^2$ $= (x_1^2, \sqrt{2}x_1x_2, x_2^2)(z_1^2, \sqrt{2}z_1z_2, z_2^2)^{\mathrm{T}}$ $= \phi(\mathbf{x})^{\mathrm{T}} \phi(\mathbf{z})$

2 fois 4 multiplications (construire $\phi(\mathbf{x})$ et $\phi(\mathbf{z})$) suivi de 3 multiplications et 2 additions (produit scalaire)



Sujets: noyau polynomial

Une forme générale est le noyau polynomial

$$k(\mathbf{x}, \mathbf{x}') = (\mathbf{x}^{\mathrm{T}}\mathbf{x}' + c)^{M}$$

où c est une constante >0

• On peut montrer que le $\phi(\mathbf{x})$ implicite contient tous les produits possibles entre au plus M éléments de x $\phi(\mathbf{x}) = (c_0,$



Sujets: noyau polynomial

Une forme générale est le noyau polynomial

$$k(\mathbf{x}, \mathbf{x}') = (\mathbf{x}^{\mathrm{T}}\mathbf{x}' + c)^{M}$$

où c est une constante >0

• On peut montrer que le $\phi(\mathbf{x})$ implicite contient tous les produits possibles entre au plus M éléments de x $\phi(\mathbf{x}) = (c_0, c_1 x_1, \dots, c_D x_D,$



Sujets: noyau polynomial

Une forme générale est le noyau polynomial

$$k(\mathbf{x}, \mathbf{x}') = (\mathbf{x}^{\mathrm{T}}\mathbf{x}' + c)^{M}$$

où c est une constante >0

• On peut montrer que le $\phi(\mathbf{x})$ implicite contient tous les produits possibles entre au plus M éléments de x

$$\phi(\mathbf{x}) = (c_0, c_1 x_1, \dots, c_D x_D, c_{11} x_1^2, c_{12} x_1 x_2, \dots, c_{11} x_1^2, c_{12} x_1 x_2, \dots, c_{$$



Sujets: noyau polynomial

Une forme générale est le noyau polynomial

$$k(\mathbf{x}, \mathbf{x}') = (\mathbf{x}^{\mathrm{T}}\mathbf{x}' + c)^{M}$$

où c est une constante >0

• On peut montrer que le $\phi(\mathbf{x})$ implicite contient tous les produits possibles entre au plus M éléments de x

$$\phi(\mathbf{x}) = (c_0, c_1 x_1, \dots, c_D x_D, c_{11} x_1^2, c_{12} x_1 x_2, \dots, c_{111} x_1^3, c_{112} x_1^2 x_2, c_{123} x_1 x_2 x_3, \dots)$$



Sujets: nombre de paramètres

• Notre modèle de régression aura plus de paramètres

• pour M=3 ,on a maintenant $1+D+D^2+D^3$ paramètres

- De façon générale, augmente selon $O(D^M)$!
 - pour D=100, M=3, on a déjà plus d'un million de paramètres





Sujets: nombre de paramètres

• Notre modèle de régression aura plus de paramètres



▶ pour M = 3 ,on a maintenant $1 + D + D^2 + D^3$ paramètres

• De façon générale, augmente selon $O(D^M)$!

 \rightarrow pour D=100, M=3, on a déjà plus d'un million de paramètres



Sujets: nombre de paramètres

• Notre modèle de régression aura plus de paramètres



▶ pour M = 3 ,on a maintenant $1 + D + D^2 + D^3$ paramètres

On n'a plus à apprendre un paramètre w explicitement !

→ pour D=100, M=3, on a déjà plus d'un million de paramètres

HUGO LAROCHELLE

De façon gé



Sujets: malédiction de la dimensionnalité

- La difficulté à bien généraliser peut donc potentiellement augmenter **exponentiellement** avec la dimensionnalité D des entrées
- Cette observation est appelée la malédiction de la dimensionnalité

- Nécessite le design de modèles / algorithmes appropriés pour chaque problème
 - on cherche des modèles / algorithmes qui vont bien exploiter les données à notre disposition



Sujets: malédiction de la dimensionnalité

• La difficulté à bien généraliser peut donc potentiellement augmenter **exponentiellement** avec la dimensionnalité D des entrées

On risque quand même d'être victime de sur-apprentissage, lorsque la dimensionnalité (implicite) de $\phi(\mathbf{x})$ augmente

- Nécessite le design de modèles / algorithmes appropriés pour chaque problème
 - on cherche des modèles / algorithmes qui vont bien exploiter les données à notre disposition







ASTUCE DU NOYAU

Sujets: astuce du noyau

- L'astuce du noyau vise à exploiter cet observation
 - peut-on définir des noyaux tels que calculer $k(\mathbf{x}_n, \mathbf{x}_m)$ est plus efficace que de calculer $\phi(\mathbf{x}_n)$ et $\phi(\mathbf{x}_m)$ et ensuite faire $\phi(\mathbf{x}_n)^{\mathrm{T}} \phi(\mathbf{x}_m)$?



Sujets: noyau polynomial

Une forme générale est le noyau polynomial

$$k(\mathbf{x}, \mathbf{x}') = (\mathbf{x}^{\mathrm{T}}\mathbf{x}' + c)^{M}$$

où c est une constante >0

• On peut montrer que le $\phi(\mathbf{x})$ implicite contient tous les produits possibles entre au plus M éléments de x

$$\phi(\mathbf{x}) = (c_0, c_1 x_1, \dots, c_D x_D, c_{11} x_1^2, c_{12} x_1 x_2, \dots, c_{111} x_1^3, c_{112} x_1^2 x_2, c_{123} x_1 x_2 x_3, \dots)$$



CONSTRUCTION DE NOYAUX

Sujets: construction de noyau

• Règles pour **construire de nouveaux noyaux** valides

$$k(\mathbf{x}, \mathbf{x}') = ck_1(\mathbf{x}, \mathbf{x}') \qquad k(\mathbf{x}, \mathbf{x}') = f(\mathbf{x})k_1(\mathbf{x}, \mathbf{x}')f(\mathbf{x}') \qquad k(\mathbf{x}, \mathbf{x}') = k(\mathbf{x}, \mathbf{x}') = k(\mathbf{x}, \mathbf{x}') \qquad k(\mathbf{x}, \mathbf{x}') = k(\mathbf{x}, \mathbf{x}') = k(\mathbf{x}, \mathbf{x}') \qquad k(\mathbf{x}, \mathbf{x}') = k(\mathbf{x}, \mathbf{x}') = k(\mathbf{x}, \mathbf{x}') \qquad k(\mathbf{x}, \mathbf{x}') = k(\mathbf{x}, \mathbf{x}') = k(\mathbf{x}, \mathbf{x}') \qquad k(\mathbf{x}, \mathbf{x}') = k(\mathbf{x}, \mathbf{x}') = k(\mathbf{x}, \mathbf{x}') \qquad k(\mathbf{x}, \mathbf{x}') = k(\mathbf{x}, \mathbf{x}') \qquad k(\mathbf{x}, \mathbf{x}') = k(\mathbf{x}, \mathbf{x}') \qquad k(\mathbf{x}, \mathbf{x}') = k(\mathbf{x}, \mathbf{x}') = k(\mathbf{x}, \mathbf{x}') \qquad k(\mathbf{x}, \mathbf{x}') = k(\mathbf{x}, \mathbf{x}') = k(\mathbf{x}, \mathbf{x}') \qquad k(\mathbf{x}, \mathbf{x}') = k(\mathbf{x}, \mathbf{x}') = k(\mathbf{x}, \mathbf{x}') \qquad k(\mathbf{x}, \mathbf{x}') = k(\mathbf{x}, \mathbf{x}') \qquad k(\mathbf{x}, \mathbf{x}') = k(\mathbf{x}, \mathbf{x}') \qquad k(\mathbf{x}, \mathbf{x}') = k(\mathbf{x}, \mathbf{x}') = k(\mathbf{x}, \mathbf{x}') \qquad k(\mathbf{x}, \mathbf{x}') = k(\mathbf{x}, \mathbf{x}') = k(\mathbf{x}, \mathbf{x}') \qquad k(\mathbf{x}, \mathbf{x}') = k(\mathbf{x}, \mathbf{x}') = k(\mathbf{x}, \mathbf{x}') = k(\mathbf{x}, \mathbf{x}') \qquad k(\mathbf{x}, \mathbf{x}') = k$$

où c > 0, $f(\mathbf{x})$ est une fonction, q(a) est un polynôme avec coefficients positifs, A est une matrice définie positive et $\mathbf{x} = (\mathbf{x}_a, \mathbf{x}_b)$. Les noyaux k_1 , k_2 , k_3 , k_a et k_b doivent être valides.



 $= k_1(\mathbf{x}, \mathbf{x}')k_2(\mathbf{x}, \mathbf{x}')$ $= k_3(\boldsymbol{\phi}(\mathbf{x}), \boldsymbol{\phi}(\mathbf{x}'))$ $= \mathbf{x}^{\mathrm{T}} \mathbf{A} \mathbf{x}'$ $= k_a(\mathbf{x}_a, \mathbf{x}'_a) + k_b(\mathbf{x}_b, \mathbf{x}'_b)$ $= k_a(\mathbf{x}_a, \mathbf{x}'_a)k_b(\mathbf{x}_b, \mathbf{x}'_b)$

CONSTRUCTION DE NOYAUX

Sujets: construction de noyau

• Exemple : $ck_1(\mathbf{x}, \mathbf{x'})$ où c > 0

$$ck_1(\mathbf{x}, \mathbf{x}') = c\phi^1(\mathbf{x})^{\mathrm{T}} \phi^1(\mathbf{x}')$$
$$= \left(\sqrt{c}\phi^1(\mathbf{x})\right)^{\mathrm{T}} \left(\sqrt{c}\phi^1(\mathbf{x}')\right)$$
$$= \phi(\mathbf{x})^{\mathrm{T}} \phi(\mathbf{x}')$$



Sujets: noyau gaussien

• Un noyau souvent utilisé est le **noyau gaussien** :

$$k(\mathbf{x}, \mathbf{x}') = \exp\left(-\|\mathbf{x} - \mathbf{x}'\|^2 / 2\sigma^2\right)$$

• Est valide puisque :

$$\|\mathbf{x} - \mathbf{x}'\|^2 = \mathbf{x}^{\mathrm{T}}\mathbf{x} + (\mathbf{x}')^{\mathrm{T}}\mathbf{x}' - 2\mathbf{x}^{\mathrm{T}}\mathbf{x}'$$

$$k(\mathbf{x}, \mathbf{x}') = \exp\left(-\mathbf{x}^{\mathrm{T}}\mathbf{x}/2\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp$$



Sujets: noyau gaussien

• Un noyau souvent utilisé est le **noyau gaussien** :

$$k(\mathbf{x}, \mathbf{x}') = \exp\left(-\|\mathbf{x} - \mathbf{x}'\|^2 / 2\sigma^2\right)$$

• Est valide puisque :

$$\|\mathbf{x} - \mathbf{x}'\|^2 = \mathbf{x}^{\mathrm{T}}\mathbf{x} + (\mathbf{x}')^{\mathrm{T}}\mathbf{x}' - 2\mathbf{x}^{\mathrm{T}}\mathbf{x}'$$

$$k(\mathbf{x}, \mathbf{x}') = \exp\left(-\mathbf{x}^{\mathrm{T}}\mathbf{x}/2\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right)\exp$$

HUGO LAROCHELLE

$k(\mathbf{x}, \mathbf{x}') = ck_1(\mathbf{x}, \mathbf{x}')$

 $p\left(-(\mathbf{x}')^{\mathrm{T}}\mathbf{x}'/2\sigma^2\right)$

Sujets: noyau gaussien

• Un noyau souvent utilisé est le **noyau gaussien** :

$$k(\mathbf{x}, \mathbf{x}') = \exp\left(-\|\mathbf{x} - \mathbf{x}'\|^2 / 2\sigma^2\right)$$

• Est valide puisque :

$$\|\mathbf{x} - \mathbf{x}'\|^2 = \mathbf{x}^{\mathrm{T}}\mathbf{x} + (\mathbf{x}')^{\mathrm{T}}\mathbf{x}' - 2\mathbf{x}^{\mathrm{T}}\mathbf{x}'$$

$$k(\mathbf{x}, \mathbf{x}') = \exp\left(-\mathbf{x}^{\mathrm{T}}\mathbf{x}/2\sigma^{2}\right) \exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^{2}\right) \exp\left(\mathbf{x}^{\mathrm$$

HUGO LAROCHELLE

$k(\mathbf{x}, \mathbf{x}') = ck_1(\mathbf{x}, \mathbf{x}')$ $k(\mathbf{x}, \mathbf{x}') = \exp(k_1(\mathbf{x}, \mathbf{x}'))$

 $p\left(-(\mathbf{x}')^{\mathrm{T}}\mathbf{x}'/2\sigma^2\right)$

Sujets: noyau gaussien

• Un noyau souvent utilisé est le **noyau gaussien** :

$$k(\mathbf{x}, \mathbf{x}') = \exp\left(-\|\mathbf{x} - \mathbf{x}'\|^2 / 2\sigma^2\right)$$

• Est valide puisque :

$$\|\mathbf{x} - \mathbf{x}'\|^2 = \mathbf{x}^{\mathrm{T}}\mathbf{x} + (\mathbf{x}')^{\mathrm{T}}\mathbf{x}' - 2\mathbf{x}^{\mathrm{T}}\mathbf{x}'$$

$$k(\mathbf{x}, \mathbf{x}') = \exp\left(-\mathbf{x}^{\mathrm{T}}\mathbf{x}/2\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^2\right)\exp\left(\mathbf{x}^{\mathrm{T}}\mathbf{x}'/\sigma^$$

$k(\mathbf{x}, \mathbf{x}') = ck_1(\mathbf{x}, \mathbf{x}')$ $k(\mathbf{x}, \mathbf{x}') = \exp(k_1(\mathbf{x}, \mathbf{x}'))$ $k(\mathbf{x}, \mathbf{x}') = f(\mathbf{x})k_1(\mathbf{x}, \mathbf{x}')f(\mathbf{x}')$

 $\exp\left(-(\mathbf{x}')^{\mathrm{T}}\mathbf{x}'/2\sigma^2\right)$

Sujets: noyau gaussien

• Un noyau souvent utilisé est le **noyau gaussien** :

$$k(\mathbf{x}, \mathbf{x}') = \exp\left(-\|\mathbf{x} - \mathbf{x}'\|^2 / 2\sigma^2\right)$$

• On peut même montrer que le $\phi(\mathbf{x})$ est un vecteur de taille infinie !

CONSTRUCTION DE NOYAUX

Sujets: construction de noyaux

- On peut également définir des noyaux pour des entrées qui ne sont pas des vecteurs \mathbf{x} de taille fixe
 - chaînes de caractères
 - ensembles de vecteurs
 - ▶ etc.

- Noyau de Fisher : un paradigme pour dériver de nouveaux noyaux à partir de modèles probabilistes génératifs
 - voir fin de la section 6.2







RÉGRESSION À NOYAU

N

Sujets: résumé de la régression à noyau

• Modèle : $y(\mathbf{x}) = \mathbf{w}^{\mathrm{T}} \boldsymbol{\phi}(\mathbf{x}) = \mathbf{k}(\mathbf{x})^{\mathrm{T}} \mathbf{a} = \sum a_n k(\mathbf{x}, \mathbf{x}_n)$ n=1

$$p(t|\mathbf{x},\beta) = \mathcal{N}(t|y(\mathbf{x}),\beta^{-1})$$

- Entraînement : $\mathbf{a} = (\mathbf{K} + \lambda \mathbf{I}_N)^{-1} \mathbf{t}$
- Hyper-paramètres : λ et ceux dans le noyau $k(\mathbf{x}, \mathbf{x}_n)$
 - c et M pour le noyau polynomial
 - σ^2 pour le noyau gaussien
- Prédiction : $y(\mathbf{x})$





CAPACITÉ ET NOYAU

N

Sujets: lien entre capacité et noyau

• Modèle :
$$y(\mathbf{x}) = \mathbf{w}^{\mathrm{T}} \boldsymbol{\phi}(\mathbf{x}) = \mathbf{k}(\mathbf{x})^{\mathrm{T}} \mathbf{a} = \sum_{n=1}^{\infty} a_n k(\mathbf{x})^{\mathrm{T}} \mathbf{a}$$

• Noyau polynomial
$$k(\mathbf{x}, \mathbf{x}') = (\mathbf{x}^{\mathrm{T}}\mathbf{x}' + c)^{M}$$

plus M est grand, plus le modèle a de la capacité

- Noyau gaussien $k(\mathbf{x}, \mathbf{x}') = \exp\left(-\|\mathbf{x} \mathbf{x}'\|^2/2\sigma^2\right)$
 - plus σ^2 est petit, plus le modèle a de la capacité



